

# Paleofish Mitochondries

Objectif : Détermination des références reconstructibles

# Suivi du projet

Demande de compte sur :  
<https://forge-dga.jouy.inra.fr/>

Quel work projet ?



The screenshot shows a project management interface for the "Paleofish\_mito" project. At the top, there's a navigation bar with links for Accueil, Ma page, Projets, and Aide. Below the title "Paleofish\_mito", there are several tabs: Aperçu, Activité, Demandes, Nouvelle demande, Gantt, and Calendrier. The "Wiki" tab is currently selected. The main content area contains a section titled "Wiki" with a list of tasks and sub-tasks:

- 1- Tests d'alignement multiple sur échantillons sélectionnés
  - L2-6 TP1 France Roquemissou (Aveyron) Néolithique (-6000 -2200)
  - Test sur échantillons moins riches en ADN
  - Générer une nouvelle référence
- 2- Détermination des références reconstructibles
  - 2-1. Calculs de couverture
  - 2-2. Second alignement pour récupérer de la profondeur
    - A. Détermination de la bonne référence
    - B. Second alignement
    - C. Comparaison des profondeurs avant et après le 2nd alignement
  - 2-3. Comparaison des affiliations entre nos runs et les données sources
- 3- Pipeline pour l'ensemble des samples
  - 3-1. Selon "Assembly and analysis of the complete mitochondrial genome of *Forsythia suspensa*"
    - 1 - Fichiers entrants: fasta de chaque mitochondrie
    - 2- Alignements multiples avec MAFFT à partir des mitochondries complètes.
    - 2- Estimation de l'arbre phylogénétique avec RAxML v8.2.10
  - 3-2. Selon "Complete Mitochondrial Genome Sequence of *Mansonella perstans*"
    - 1- Alignements multiples avec MAFFT v7.427
    - 2- IQ-TREE v1.6.2 run with ModelFinder
    - 3- 1,000 ultrafast bootstrap replicates
    - 4- iTOL v5

# Point sur les 89 échantillons

\* Au moins 12 FASTQ corrompus (Nb séquences R1/R2 différent → Buffer error)

Listés dans le wiki (accès wiki ?) :

L10\_1\_BC5\_S58

L10\_11 SCO\_1338\_S63

L11\_2 SCO\_81\_S67

L11\_6 SCO\_116\_S69

L2\_11 MPHB3\_S79

L4\_11 MD2\_S21

L4\_9 MD12\_S19

L5\_1 MD15\_S26

L5\_11 MD14\_S36

L6\_11 SH2000-99-394-g\_S46

L6\_6 SH2001-106\_11-b\_S44

L7\_14\_7013j\_S48\_R1\_001-bonnom.fastq.gz

\* 12 FASTQ ne sont pas disponibles dans le répertoire ECOBIOP\_ADNa: L1-1, L1-4, L7-15, L8-6, L9-12, L9-8, L9-10, L3-3, L7-11, L7-9, L1-2, L1-7

→ Une autre source est-elle disponible ? ng6 ? Disque dur ?

# Premiers tests

Un échantillon L2-6 TP1 France Roquemissou (Aveyron) Néolithique (-6000 -2200).


```
 samtoobash-4.4$ samtools idxstats L2_6_TP1_S75.sort.bam
NC_010007.1      16677  196145  1487
NC_025589.1      16751   3696    53
NC_025648.1      16737   2240    17
NC_028593.1      16736   1969    21
NC_030175.1      16739   2086    29
NC_001960.1      16665   10558   97
*                 0       0       44930
```

→ mapDamage inutile pour trouver les vrais variants car la profondeur est telle que les dommages faits à l'ADN sont masqués.


# Premiers tests

[http://genoweb.toulouse.inra.fr/~sigenae/sarah/mito/igvjs\\_multifasta.html](http://genoweb.toulouse.inra.fr/~sigenae/sarah/mito/igvjs_multifasta.html)


## Multi align L2\_6\_TP1\_S75



## Multi align L2\_6\_TP1\_S75



# Premiers tests : Bonne qualité du consensus



# Alignement sur multiFasta

- TODO :**
- Graph Qte ADN \* Nb seq.
  - Histo Nb seq. / éch.
  - Histo Nb seq. alignées

**Choix de 5 références pour générer un multifasta :** (source PartitionCaptureMitoParLot.xlsx):

Salmo trutta trutta NC\_010007.1

Hucho hucho mitochondrion NC\_025589.1

Coregonus muksun mitochondrion NC\_028593.1

Coregonus ussuriensis mitochondrion NC\_025648.1

Coregonus chadary mitochondrion NC\_030175.1

(puis ajout salmo salar dans la suite des tests)

**Alignement sur 5 échantillons moins riches en ADN :**

lib	[DNA] ng/ul	endo %
L9-13	15,5	1,1
L2-4	9,6	0,9
L5-6	29,8	0,8
L9-4	46,9	0,8
L9-14	27,1	0,8
L5-11	26,6	0,6
L9-6	31,3	0,6

Nb. align. seq. (1)

Sample	NC_010007.1	NC_025589.1	NC_025648.1	NC_028593.1	NC_030175.1	NC_001960.1
L9_14_SH1979-4-6843-a_S56	5687	226	100	75	74	503
L5_6_MB8_S31	1403	602	252	272	241	19719
L5_11_MD14_S36	97040	3487	1799	1723	1802	9437
L9_6_SH1979-4-6843-b_S53	21848	605	322	302	293	1617
L2_4_CD2_S74	15	3	12	1	2	15

(1) Nombre de séquences alignées pour chaque référence ([samtools idxstats troisième colonne](#))

→ Pas de corrélation entre le nombre de séquences et la quantité d'ADN.


# Alignement sur multiFasta

Nb. align. seq. (1)


Sample	NC_010007.1	NC_025589.1	NC_025648.1	NC_028593.1	NC_030175.1	NC_001960.1
L9_14_SH1979-4-6843-a_S56	5687	226	100	75	74	503

```
bash-4.4$ samtools idxstats L9_14_SH1979-4-6843-a_S56
NC_010007.1      16677   5687   91
NC_025589.1      16751   226    3
NC_025648.1      16737   100    0
NC_028593.1      16736   75     2
NC_030175.1      16739   74     0
NC_001960.1      16665   503    5
```

## Multi align L9\_14\_SH1979-4-6843-a\_S56



## Multi align L9\_14\_SH1979-4-6843-a\_S56




# Alignement sur multiFasta

Zoom sur zones moins couvertes :



Zoom sur zones coloriées dans histogramme → Consensus ok



# Alignement & Sélection

1/ Alignement de l'ensemble des échantillons disponibles avec le multifasta pour récupérer le nb. De séquences alignées et les profondeurs :



PaleoFish\_mito\_V2  
.ods

2/ Critères de sélection des 27 échantillons :

- 2/3 échantillons par période distincte
- avec une couverture médiane variable : haute - moyenne – basse

Id	Period	sample	mean coverage	median coverage	Ref principale en fonction du nb seq. alignées
L6-11	4400-4000BC	L6_11_SH2000-99-394-g_S46	340,431	630,5	Salmo trutta NC_010007.1 (137754)
L9-15	4400-4000BC	L9_15_SH2000-99-390-c_S57	147,295	223	Salmo trutta NC_010007.1 (44148)
L6-6	4900-4500BC	L6_6_SH2001-106_11-b_S44	32,1258	27	Salmo trutta NC_010007.1 (9938)
L6-4	800-1000 AD =VIKING PERIOD	L6_4_SH1979-4-6843-c_S42	179,328	324,5	Salmo trutta NC_010007.1 (67175)
L6-3	800-1000 AD =VIKING PERIOD	L6_3_SH1979-4-6843-e_S41	132,26	165	Salmo trutta NC_010007.1 (41909)
L9-14	800-1000 AD =VIKING PERIOD	L9_14_SH1979-4-6843-a_S56	20,7994	11	Salmo trutta NC_010007.1 (5687)
L5-6	azilien	L5_6_MB8_S31	59,6934	102	Salmo salar NC_001960.1 (19719)
L4-4	azilien	L4_4_MB9_S14	147,054	45	Salmo salar NC_001960.1 (59671)
L11-6	Late Neolithic (c. 2800 BC)	L11_6 SCO_116_S69	175,585	128	Salmo trutta NC_010007.1 (49085)
L11-3	Late Neolithic (c. 2800 BC)	L11_3 SCO_114_S68	89,1935	47	Salmo trutta NC_010007.1 (24367)
L10-11	Later medieval and post medieval (1400-1800 AD)	L10_11 SCO_1338_S63	499,582	577	Salmo salar NC_001960.1 (166059)
L11-7	Later medieval and post medieval (1400-1800 AD)	L11_7 SCO_1354_S70	291,815	123	Hucho hucho NC_025589.1(10302)
L5-1	magdalénien = paléolithique supérieur	L5_1 MD15_S26	360,818	615	Salmo salar NC_001960.1 (177582)
L5-12	magdalénien = paléolithique supérieur	L5_12 MD9_S37	191,109	333	Salmo salar NC_001960.1 (69810)
L5-2	magdalénien = paléolithique supérieur	L5_2 MD7_S27	79,2106	16	Salmo salar NC_001960.1 (27828)
L2-10	Médiéval	L2_10 MPH2B2_S78	397,896	725	Salmo salar NC_001960.1 (139394)
L2-11	Médiéval	L2_11 MPH3B3_S79	251,258	341,5	Salmo salar NC_001960.1 (81468)
L10-4	Moderne (XVIIe siècle)	L10_4 BC8_S61	528,619	834	Salmo trutta NC_010007.1 189670()
L10-1	Moderne (XVIIe siècle)	L10_1 BC5_S58	311,279	416,5	Salmo trutta NC_010007.1 (114132)
L10-5	Moderne (XVIIe siècle)	L10_5 BC9_S62	117,123	116	Salmo trutta NC_010007.1 (38431)
L2-7	Néolithique	L2_7 TP2_S76	859,351	1825	Salmo trutta NC_010007.1 (302730)
L2-6	Néolithique	L2_6 TP1_S75	527,888	496,5	Salmo trutta NC_010007.1 (196145)
L3-5	Paléolithique supérieur (Azilien)	L3_5 SM3_S2	311,605	526,5	Salmo trutta NC_010007.1 (96592)
L9-4	Paléolithique supérieur (Azilien)	L9_4 SM1_S52	10,1096	8	Salmo salar NC_001960.1 (3186)
L0-4	Paléolithique supérieur (Magdalénien)	L0_4 EG9_S84	55,5137	127,5	Salmo salar NC_001960.1 (7607)
L0-6	Paléolithique supérieur (Magdalénien)	L0_6 EG13_S86	167,66	50	Salmo trutta NC_010007.1 (71382)
L2-3	Paléolithique supérieur (Magdalénien)	L2_3 EG3_S73	80,2654	8	Salmo salar NC_001960.1 (30140)

# Alignement sur référence majoritaire

- Second l'alignement que sur la référence majoritaire de chaque échantillon  
→ pour éviter de dépeupler des zones qui sont partagées entre plusieurs références.
- Ajout d'un filtre sur la qualité des alignements : -q 20
- Profondeur min assez grande pour avoir confiance dans la référence.
- Comparaison des profondeurs min et max :
  - au 1<sup>er</sup> alignement : sur multifasta et non filtré
  - vs 2nd alignement : sur référence majoritaire et bam filtré q 20

→ Ceci nous permet donc effectivement de récupérer de la profondeur
- Explorations manuelles :  
[http://genoweb.toulouse.inra.fr/~sigenae/sarah/mito/Second-pass-align/L0\\_4.igvjs.html](http://genoweb.toulouse.inra.fr/~sigenae/sarah/mito/Second-pass-align/L0_4.igvjs.html)


sample	Ref. maj.	1st align. min	1st align. max	2nd align. min	2nd align. max	IGV
L0_4	NC_001960.1	0	571	0	930	IGV
L0_6	NC_010007.1	2	1103	2	1120	IGV
L10_1 *	NC_010007.1	25	1035	57	1052	IGV
L10_11 *	NC_001960.1	1	1536	28	1537	IGV
L10_4	NC_010007.1	43	1643	173	1642	IGV
L10_5	NC_010007.1	6	389	22	407	IGV
L11_3	NC_010007.1	3	248	13	289	IGV
L11_6 *	NC_010007.1	1	737	1	737	IGV
L11_7	NC_025589.1	0	2172	1	4418	IGV
L2_10	NC_001960.1	1	1115	35	1115	IGV
L2_11 *	NC_001960.1	1	689	18	748	IGV
L2_3	NC_001960.1	1	293	6	293	IGV
L2_6	NC_010007.1	51	1996	92	2006	IGV
L2_7	NC_010007.1	119	2626	283	2630	IGV
L3_5	NC_010007.1	24	1044	93	1048	IGV
L4_4	NC_001960.1	2	1274	22	1274	IGV
L5_1 *	NC_001960.1	1	1520	31	1527	IGV
L5_12	NC_001960.1	1	613	18	621	IGV
L5_2	NC_001960.1	1	246	14	263	IGV
L5_6	NC_001960.1	1	301	1	305	IGV
L6_11 *	NC_010007.1	19	1631	103	1635	IGV
L6_3	NC_010007.1	8	462	25	462	IGV
L6_4	NC_010007.1	17	867	42	867	IGV
L6_6 *	NC_010007.1	1	148	1	157	IGV
L9_14	NC_010007.1	1	104	1	136	IGV
L9_15	NC_010007.1	12	437	27	437	IGV
L9_4 *	NC_001960.1	0	54	*	*	IGV

# Alignement sur référence majoritaire IGV L0\_6

[http://genoweb.toulouse.inra.fr/~sigenae/sarah/mito/Second-pass-align/L0\\_6.igvjs.html](http://genoweb.toulouse.inra.fr/~sigenae/sarah/mito/Second-pass-align/L0_6.igvjs.html)

Zoom sur zones moins couvertes = zones dégradées:

- Même si trou => Blocs de N. Tant que la profondeur n'est pas nulle alors la référence est bonne.
- Même si dégradé -> consensus possible.
- Hétérozygotie, mais pas trop de variations différentes dans les différentes séquences => consensus propre.




Zoom sur quelques petites variations aléatoires qui ne changent pas le référence :

# Perspectives



## Démarche pour générer les nouvelles références:

- Contrôler la qualité des alignements avec IGV.
- Sélectionner les échantillons à conserver (avec Joëlle).
- Extraire la séquence consensus de référence en sélectionnant un groupe d'échantillons ayant la même référence majoritaire. Par exemple, les 8 échantillons truite.



# Perspectives

- Générer une nouvelle référence consensus avec les seconds alignements sur ces échantillons avec un outil d'alignement multiple comme MAFFT.
- Analyse phylogénétique (dendrogramme) pour calculer la distance entre les références générées.
- Analyse des variants entre les références et replacer les individus par rapport aux variants.



# Perspectives

 **BMC** Part of Springer Nature

**BMC Genomics**

Home About Articles Submission Guidelines Collections Join The Board [Submit manuscript](#) 

Research | [Open access](#) | Published: 23 November 2023

## Assembly and analysis of the complete mitochondrial genome of *Forsythia suspensa* (Thunb.) Vahl

[Yun Song](#) , [Xiaorong Du](#), [Aoxuan Li](#), [Amei Fan](#), [Longjiao He](#), [Zhe Sun](#), [Yanbing Niu](#) & [Yonggang Qiao](#) 

[BMC Genomics](#) 24, Article number: 708 (2023) | [Cite this article](#)

545 Accesses | 1 Altmetric | [Metrics](#)

 National Library of Medicine  
National Center for Biotechnology Information

 PubMed Central®  [Search in PMC](#)

[Journal List](#) > [Microbiol Resour Announc](#) > v.9(30), 2020 Jul > PMC7378030

As a library, NLM provides access to scientific literature. Inclusion in an NLM database does not imply endorsement of, or agreement with, the contents by NLM or the National Institutes of Health.

Learn more: [PMC Disclaimer](#) | [PMC Copyright Notice](#)



[Microbiol Resour Announc](#), 2020 Jul; 9(30): e00490-20.  
Published online 2020 Jul 23. doi: [10.1128/MRA.00490-20](#)

PMCID: PMC7378030  
PMID: [32703831](#)

### Complete Mitochondrial Genome Sequence of *Mansonella perstans*

Matthew Chung,<sup>a</sup> Jain Aluvathingal,<sup>a</sup> Robin E. Bromley,<sup>a</sup> Suvarna Nadendla,<sup>a</sup> Fanny F. Fombad,<sup>d,e</sup> Chi A. Kien,<sup>d,e</sup> Narcisse V. T. Gandjui,<sup>d,e</sup> Abdel J. Njouendou,<sup>d,e</sup> Manuel Ritter,<sup>f</sup> Lisa Sadzewicz,<sup>a</sup> Luke J. Tallon,<sup>a</sup> Samuel Wanji,<sup>d,e</sup> Achim Hoerauf,<sup>f,g</sup> Kenneth Pfarr,<sup>f,g</sup> and Julie C. Dunning Hotopp<sup>Ka,b,c</sup>

# Conclusion

- Grandes variabilités sur les quantités de séquences produites.
- Certains échantillons corrompus ou absents ~ 30 perdus / 89.
- Beau potentiel avec ~ 20-30 truites et ~20 saumon.
- Voir si des zones géographiques et des périodes historiques sont perdues.